Zeszyty Naukowe AON nr 4(89) 2012
ISSN 2299-6753

OD INTELIGENCJI ROJU DO WIELOAGENTOWYCH SYSTEMÓW DO NAWIGACJI ROBOTÓW MOBILNYCH

dr Emilia MIKOŁAJEWSKA
Wojskowy Szpital Kliniczny w Bydgoszczy

mjr rez. mgr inż. Dariusz MIKOŁAJEWSKI
Uniwersytet Mikołaja Kopernika w Toruniu

Streszczenie

Inteligencja roju jest uważana za złożone zachowania społeczne wyłaniające się z prostych interakcji pomiędzy prostymi agentami. Wywodzi się ona z kolektywnego zachowania wzorców naturalnych, takich jak kolonie mrówek, może być jednak zaadaptowana do systemów sztucznych. Stwarza to kolejne możliwości medycznego oraz militarnego wykorzystania technologii inteligencji roju np. do nawigacji mobilnymi robotami. Artykuł stanowi próbę oceny, w jakim stopniu wykorzystuje się możliwości w omawianym zakresie.

Słowa kluczowe – robotyka, sztuczna inteligencja, inteligencja roju, zastosowania wojskowe, roboty pola walki

Wprowadzenie

Z pewnością niejeden dowódca, obserwując zgrane, błyskawiczne manewry klucza ptaków czy ławicy ryb, zastanawiał się, jak to jest możliwe i marzył o takim zgraniu własnych pododdziałów. Nie jest to do końca fantazja naukowa – naukowcy już dawno dostrzegli korzyści płynące z naśladowania natury, a techniki informatyczne oparte na wzorcach naturalnych znalazły swoje odzwierciedlenie m.in. w sztucznych sieciach neuronowych (ang. Artificial Neural Networks – ANN), algorytmach genetycznych (ang. Genetic Algorithms – GA), symulowanym wyżarzaniu (ang. simulated annealing) czy właśnie w inteligencji roju (ang. swarm intelligence) [1]. Rozwiązań opartych na działaniu przyrody może być wiele i z każdym dniem odkrywa się następne, jak np. komputery chemiczne (molekularne układy logiczne [2]). Dzieje się tak dlatego, że pomimo dynamicznego rozwoju nauki i techniki niektóre problemy nie mogą być rozwiązane za pomocą klasycznego sprzętu

[1] Kennedy J., Eberhart R. C. Swarm Intelligence. Morgan Kaufman Publishers, San Francisco 2001; Hantak C. Comparison of parallel hardware based and graphics hardware based platforms for swarm intelligence simulations. Integrative Paper, UNC-Chapel Hill 2003; Bonabeau E., Dorigo M., Theraulaz G. Swarm intelligence: from natural to artificial systems. Oxford University Press, Oxford 1999.

[2] Por. badania I. Willnera z Hebrew University w Jerozolimie.

komputerowego i oprogramowania. Klasyczne techniki informatyczne posiadają ograniczenia m.in. w zakresie następujących problemów:

– skomplikowanych obliczeniowo, często pomimo znanego algorytmu, m.in. gra w szachy,

– systemów adaptacyjnych, dynamicznie zmieniających się w sposób trudny do przewidzenia, m.in. zarządzanie biznesem, gra na giełdzie papierów wartościowych,

– systemy w pełni autonomiczne,

– systemy należące do kategorii logiki rozmytej, m.in. inteligentna interakcja człowiek–komputer, komunikacja za pomocą mowy.

Niemniej jednak wzorowanie się na systemach naturalnych ma również istotne ograniczenia:

– natura może iść na kompromisy przy wyborze celów, tzn. wybiera pierwszy napotkany wariant spełniający założone wymagania, a niekoniecznie wariant optymalny,

– strategie natury nie gwarantują sukcesu (tj. bywają zawodne),

– istnieją mechanizmy naturalne na chwilę obecną zbyt trudne do odtworzenia w postaci zrozumiałej dla maszyn matematycznych jakimi są komputery,

– niektóre problemy, mimo iż rozwiązywane skutecznie przez naturę, mogą być efektywniej, szybciej i/lub taniej rozwiązywane w inny sposób – wynika to z tego, że rozwiązania optymalne dla natury nie muszą być optymalne dla człowieka dysponującego szerszą paletą środków.

W przypadku inteligencji roju kluczem do poszukiwania rozwiązania było dostrzeżenie analogii między tymi problemami obliczeniowymi a naturą:

1. cel: optymalizacja wykonania zadania,

2. podstawowy zakres zastosowań:

– wyszukiwanie jakiegoś elementu (np. pożywienia),

– wybór drogi (klucz ptaków czy ławica ryb),

– transport (mrówki),

– bardziej złożone działania grupowe wynikające z działań jednostek wchodzących w skład grup (mrówek, termitów, pszczół itd.),

Do rozwiązywania podobnych problemów możliwe jest zastosowanie podobnych rozwiązań:

– wielokrotne interakcje między rozproszonymi na interesującym (z punktu widzenia realizacji zadania) obszarze autonomicznymi agentami,

– samoorganizująca się kontrola i współpraca (brak potrzeby centralnego zarządzania),

– podział pracy i alokacja zadań.

Inteligencja roju jako podstawa systemów wieloagentowych

Inteligencja roju stanowi własność systemu, w którym kolektywne zachowania prostych agentów wchodzących lokalnie w interakcje między sobą i z otoczeniem powodują wyłonienie się spójnych wzorców globalnych. Dzięki temu inteligencja

roju dostarcza szkieletu, na bazie którego możliwe jest badanie kolektywnego (rozproszonego) rozwiązywania problemów bez scentralizowanego sterowania lub zapewniania modelu globalnego. Odnosi się to do złożonych zachowań prezentowanych przez grupę (rój, kolonię) autonomicznych jednostek (agentów) wykonujących proste działania w obrębie ściśle określonego otoczenia. Złożone zachowania całej grupy, niezbędne do wykonania postawionego przed nią zadania, wyłaniają się w rezultacie zdolności grupy do samoorganizacji działań agentów. Funkcje samych agentów są z reguły proste i ściśle ograniczone, co znacznie upraszcza ich budowę. Pojedynczy agent nie posiada żadnej wiedzy globalnej (całościowej), a jedynie wiedzę lokalną na temat bezpośredniego otoczenia. Uzyskuje ją wykorzystując możliwości:

– wchodzenia w interakcje z tym najbliższym otoczeniem (wykorzystując swoje „zmysły"),

– wchodzenia w interakcje z co najmniej jednym najbliższym sąsiadem (czyli wymieniając wiedzę lokalną),

– opcjonalnie – modyfikacji otoczenia jako formy komunikacja pomiędzy agentami.

Działania agentów są również ściśle ograniczone: mogą oni jedynie poruszać się lub dokonywać modyfikacji w najbliższym otoczeniu. Decyzję, jakie działanie wykonać, agent podejmuje na podstawie bieżącego stanu najbliższego otoczenia (o ile w danym momencie czasu ma wybór). Jeśli przy danym stanie najbliższego otoczenia agent może wybrać więcej niż jedną opcję – wybór jest zwykle losowy, pomimo że jedne zachowania mogą być bardziej prawdopodobne niż inne. Ze względu na to, że poszczególni agenci są relatywnie niezależni (tzn. nie otrzymują komend od lidera grupy czy też nie postępują zgodnie z jakimś globalnym planem) można założyć, że ich zachowaniem kierują jedynie dwie przesłanki:

– wstępne zaprogramowanie – tzw. plan lokalny: reguły zachowania typu: chodź losowo, a jak trafisz na jedzenie to podnieś, zapamiętaj położenie i wracaj po swoim śladzie do grupy,

– interakcje z innymi agentami i otoczeniem – odpowiednio reguła: daj znać najbliższym sąsiadom, gdzie jest jedzenie.

W inteligencji roju wykorzystywane są dwa kluczowe mechanizmy:

– samoorganizacja tj. tworzenie struktur globalnych poprzez powtarzane interakcje lokalne, umożliwiająca niejako kolektywne podejmowanie decyzji,

– stygmergia tj. stymulacja przez pracę – niebezpośrednia komunikacja oparta na modyfikacji otoczenia, naturalny, ale dość złożony mechanizm komunikacji i kooperacji w grupie, szczególnie w przypadku np. kooperatywnego transportu.

Dzięki bezpośrednim i pośrednim interakcjom między agentami możliwa jest samoorganizacja zbiorowości i znajdowanie w sposób kolektywny rozwiązań o stopniu złożoności daleko większym niż możliwe do znalezienia przez pojedynczych agentów. Dochodzi do tego bez jakichkolwiek złożonych operacji obliczeniowych, w sposób, który można porównać z przetwarzaniem rozproszonym.

Agenci mogą uczyć się, oceniając stymulację i przyporządkowując jej znaczenie: negatywne lub pozytywne. W tym aspekcie inteligencja roju realizuje wymianę pomiędzy uczeniem się indywidualnym i zbiorowym. Na chwilę obecną nie wszystkie mechanizmy panujące w takich zbiorowościach są dla nas, ludzi, jasne i wytłumaczalne w prosty sposób. W oparciu o obecną wiedzę zasadnicze cechy inteligencji roju stanowią:

- minimalistyczne (proste i tanie), ale w pełni autonomiczne jednostki (agenci),
- w pełni rozproszone zarządzanie,
- celowe wykorzystanie interakcji agent-agent, agent-otoczenie oraz agent--otoczenie-agent,
- wykorzystanie komunikacji bezpośredniej lub pośredniej (wykorzystanie stygmergii),
- skalowalność: od kilku do wielu tysięcy agentów,
- zwiększona niezawodność dzięki redundancji (nadmiarowości) oraz minimalistycznej konstrukcji agentów (homogenicznych – jednakowych lub heterogenicznych – o zróżnicowanych funkcjach i budowie).

Tak więc skonstruowany przez człowieka sztuczny system inteligencji roju powinien być:

- prosty,
- adaptacyjny,
- stabilny – cechujący się spójnym i ukierunkowanym na cel postępowaniem agentów,
- wystarczający jakościowo – zapewniać uzyskanie rozwiązania, być może niekoniecznie najlepszego możliwego, a tylko satysfakcjonującego,
- w uzasadnionych wypadkach: zapewniający różnorodność reakcji przy tych samych warunkach.

Dotychczasowe obszary zastosowań:

- optymalizacja – np. w sieciach telekomunikacyjnych,
- robotyka,
- wzorce ruchu w systemach transportowych i produkcyjnych,
- modelowanie zachowań grupowych i społecznych.

Przykłady wykorzystania inteligencji roju stanowią:

- grupowe poszukiwanie (np. pożywienia) przez owady społeczne jako wzorzec optymalizacji obciążenia w sieciach telekomunikacyjnych oraz tzw. problemu komiwojażera,
- transport kooperacyjny u owadów społecznych – niezwykle interesujący z punktu widzenia robotyki,
- adaptacyjny podział pracy i przydział zadań u mrówek – praca nie ustaje pomimo braku centralnego zarządzania, ciągłej oceny sytuacji globalnej i systemów przekazywania poleceń – wykorzystywane w algorytmach urządzeń (w tym robotów) w sytuacjach zakłócenia funkcjonowania któregoś z systemów,

– budowanie gniazd przez owady społeczne – wykorzystywane do budowy robotów samorekonfigurujących się,

– grupowe sortowanie i grupowanie – wykorzystywane do analizy danych,

– ruch stada ptaków, ławic ryb – wykorzystanie do analizy ruchu grupowego: pieszych na chodnikach w tłumie i samochodów na ulicach w godzinach szczytu,

– symulacja „sztucznego życia" (ang. alife od: artificial life) – sztucznych światów zamieszkanych przez różne formy sztucznego życia, ewoluujące wraz z nim, aż po symulację złożonych procesów społecznych i ewolucyjnych,

– testowanie rozległych systemów i oprogramowania.

Obecnie najlepszymi technikami optymalizacji z dziedziny swarm intelligence są, w zależności od zadania:

– algorytmy mrówkowe (ang. Ant Colony Optimization – ACO),

– optymalizacja wielocząsteczkowa (ang. Particle Swarm Optimization – PSO).

Należy jednak nadmienić, że, m.in. ze względu na dużą dynamikę rozwoju oraz zróżnicowanie rozwiązań, nie zostało sformułowane jednolite kryterium oceny i porównywania systemów inteligencji roju. W praktyce realizuje się to m.in. poprzez próby symulacji, porównywanie elastyczności i odporności na błędy poszczególnych systemów (na wzór zawodów robotów, będących szybkim i efektywnym testem ich algorytmów i samodzielności).

Algorytmy mrówkowe

Kolonie zakładane przez owady społeczne (mrówki, termity, pszczoły) potrafią osiągać dość wysoki poziom realizacji złożonych zadań wymagających elastyczności i inteligencji wykorzystując do tego pojedyncze owady, które cechuje prostota, unifikacja, ale również brak wiedzy czy inteligencji. Pojedyncze owady kierują się, w oparciu o posiadane zmysły (dotyku, węchu, rzadziej słuchu), prostymi regułami niewymagającymi realizacji złożonych procesów analitycznych. Repertuar ich zachowań jest znacznie ograniczony, a pojedynczy owad nie ma dostępu do całościowej wiedzy o aktualnym stanie kolonii, jej kierunku rozwoju oraz podziale zadań. Struktura globalna, czyli np. mrowisko pewnie wyłania się z działań wielu jednostek. Zbiorowość pozostaje stabilnym, samoregulującym się organizmem, łatwo adaptującym się do zmian otoczenia, w którym się rozwija (nawet poprzez poświęcenie części jednostek) [3].

Jednym z najczęściej badanych zachowań owadów społecznych jest sposób, w jaki przeszukują one teren oraz poszukują jedzenia. Pomimo faktu, że pojedyncza mrówka może przeszukać jedynie bardzo ograniczony teren mrówki kooperują ze sobą np. by eksploatować źródło pożywienia znalezione w trakcie poszukiwań przez jedną z nich. Grupowe zachowania kolonii mrówek są rezultatem złożenia

[3] Dorigo M., Stützle T. Ant Colony Optimization. MIT Press, Massachusets 2004; Dorigo M., Di Caro G. Ant Algorithms for Discrete Optimization. Artificial Life, 1999, 5(3): 137-172.

interakcji między wieloma pojedynczymi mrówkami kolonii. Dlatego możliwe jest wynikowe (często skomplikowane) zachowanie kolonii pomimo prostych reguł rządzących zachowaniem każdej mrówki.

Pierwsze próby wykorzystania wzorców zachowania się mrówek do rozwiązywania problemów optymalizacyjnych miały miejsce w późnych latach 80. XX wieku. Mrówki stanowiły wówczas ideowy model biologiczny do stworzenia symulacji komunikacji za pomocą feromonu. Dalszy rozwój tego modelu doprowadził do powstania algorytmów mrówkowych (ACO)[4], używanych do rozwiązywania różnorodnych problemów związanych z optymalizacją. Pierwszy modelowy system ACO został zaprezentowany przez Bonabeau i jego współpracowników w 1989 roku. Obejmował on proste reguły rządzące zachowaniem się odpowiedników pojedynczych mrówek (zwanych agentami) w poruszającej się kolumnie. Sposób komunikacji między mrówkami zakłada komunikację niebezpośrednią z wykorzystaniem feromonu – substancji chemicznej, którą mrówki mogą wydzielać pozostawiając za sobą ślad (szlak, ścieżkę) przyciągający inne mrówki. W ten sposób większe stężenie feromonu oznacza drogę, po której przedtem przeszła większa liczba mrówek, a brak feromonu – drogę, którą jeszcze nie przeszła mrówka. Ponieważ mrówki mogą feromon wydzielać lub też nie – pozostawienie ścieżki feromonowej oznacza „wezwanie do pomocy" innych mrówek w celu łatwiejszego transportu pożywienia do mrowiska. Oczywiście feromon paruje i z czasem ulatnia się zupełnie i, o ile nie będzie odświeżany przez inne mrówki, zaniknie i mrówki nie będą już podążały do źródła pożywienia, być może do tego czasu zupełnie wyeksploatowanego. Na powyższe zdolności nakłada się umiejętność odnajdywania najkrótszej drogi od źródła pożywienia do mrowiska. Główną rolę odgrywają tu znowu ścieżki feromonowe. Mrówki tworzą (i utrzymują) drogę poprzez znaczenie jej feromonem i regularne odświeżanie go. Ponieważ przyciąga on inne mrówki, to najkrótsza droga jest częściej uczęszczana (gdyż przejście jej trwa krócej) i tym samym częściej odświeżana, więc jeszcze bardziej przyciąga feromonem. Jako złożenie zachowania wielu mrówek tworzone jest więc rozwiązanie globalne dla całej grupy transportującej jedzenie z danego źródła pożywienia. Mechanizm ten działa analogicznie w przypadku pojawienia się przeszkody na używanej właśnie drodze i konieczności obejścia przeszkody lub znalezienia nowej drogi. Pomimo prób obejścia przeszkody z obu stron z czasem częściej uczęszczana staje się krótsza droga obejścia. Trzeba tu zauważyć, że w momencie obchodzenia przeszkody mrówki muszą zejść ze ścieżki feromonowej i od początku zaczyna działać mechanizm poszukiwania najkrótszej drogi, aż do ponownego natrafienia na ścieżkę feromonową za przeszkodą. Naukowcy uważają, że skoro mrówki (analogicznie

[4] Navarro Varela G., Sinclair M. C. Ant Colony Optimisation for virtual-wavelength-path routing and wavelength allocation. Materiały Congress on Evolutionary Computation (CEC'99), 1999; White T., Bieszczad A., Pagurek B. Distributed fault location in networks using mobile agents. Materiały 3rd International Workshop on Agents in Telecommunication Applications IATA'98, 1998.

termity, pszczoły itd.) wypracowały takie mechanizmy w ciągu milionów lat i przetrwały, to są one niezwykle skuteczne.

Zastępując mrówki prostymi agentami otrzymujemy gotowy system bazowy dający się łatwo dostosowywać do różnych zadań. W formie prostej analogii można wykorzystać ten mechanizm do rozwiązania tzw. problemu komiwojażera, jak również, w bardziej rozwiniętej postaci, do modelowania stanu (obciążenia) sieci telekomunikacyjnej, frachtu towarów oraz przewozu osób czy też natężenia ruchu ulicznego. Pewne aspekty ACO są również przydatne do modelowania i optymalizacji dostarczania zaopatrzenia do zakładów produkcyjnych, rozdziału zadań pomiędzy pracowników aż po całe strategie działania firm[5].

Wykorzystując algorytmy mrówkowe należy pamiętać:

– o właściwym dobraniu analogii do zadania,

– o właściwym modelowaniu otoczenia, zwłaszcza przy jego dynamicznych zmianach,

– o właściwym modelowaniu zachowań agentów, zwłaszcza heterogenicznych,

– o wykorzystywanie jak najprostszych zasad rządzących zachowaniem agentów, dobranych na bazie doświadczeń i dających pożądane zachowanie grupy, gdyż nie ograniczają one inicjatywy agentów i mogą oni realizować nieoczekiwane rozwiązania postawionego problemu, gdy rozwiązania znane staną się bezużyteczne,

– wynik będzie satysfakcjonujący (czyli: spełniający zadane kryteria), ale niekoniecznie najlepszy możliwy (optymalny).

Cechy owadów, które stanowią o ich sukcesie i które musi przejąć model są następujące:

– elastyczność – możliwość adaptacji do różnych warunków środowiska,

– niezawodność – nawet jeśli niektórzy agenci zawiodą lub też pomylą się, cała grupa wykona swoje zadanie,

– samokontrola – brak centralnego zarządzania i kontroli.

Optymalizacja wielocząsteczkowa

Idea optymalizacji wielocząsteczkowej (PSO) została rozwinięta przez psychologa społecznego Jamesa Kennedy'ego oraz inżyniera elektryka Russella Eberharta w 1995 i wywodzi się z wcześniejszych badań nad algorytmami umożliwiającymi modelowanie zachowań stadnych widzianych u wielu gatunków ptaków. Zacho-

[5] Mohamad M.M. Articulated robots motion planning using foraging ant strategy. Journal of Information Technology – Special Issues in Artificial Intelligence, 2008, 20(4): 163–181; Mohamad M.M., Taylor N.K., Dunnigan M.W. Articulated robot motion planning using Ant Colony Optimisation. Materiały 3rd International IEEE Conference on Intelligent Systems, 2006, s. 690–695; Mohamad M.M., Dunnigan M.W., Taylor N.K. Foraging Ant Motion Planning for Articulated Robots. Materiały International Joint Conference SICE-ICASE, 2006, s. 4285–4290; Mohamad M.M., Dunnigan M.W., Taylor N.K. Ant Colony Robot Motion Planning. Materiały IEEE International Conference on Computer as a Tool: EUROCON 2005, s. 213–216.

wanie stada poszukującego pożywienia wyłania się z prostych reguł rządzących ruchem ptaków:

– ustawiaj kierunek i prędkość lotu tak, aby pozostać wewnątrz stada,

– ustawiaj kierunek i prędkość lotu tak, aby nie wpaść na inne (sąsiednie) osobniki ze stada.

Gdy jakiś osobnik odlatuje ze stada w kierunku odkrytego pożywienia najbliższe mu ptaki podążają za nim w tym samym kierunku, aż same odkryją pożywienie, pociągając resztę stada za sobą. Ślepe stosowanie reguł przez członków stada ptaków (ławic ryb itp.) umożliwia im zsynchronizowany i bezkolizyjny ruch, będący efektem wysiłku każdego ptaka włożonego w utrzymanie optymalnego dystansu od swoich sąsiadów. Stąd analogia między sposobem przeszukiwania przez stado ptaków obszaru ich poszukiwań a przeszukiwaniem pola potencjalnych rozwiązań w poszukiwaniu najlepszego rozwiązania. Aby z kolei odróżnić rozwiązanie najlepsze od pozostałych pojedynczy osobnik (tzw. partykl, od ang. particle) uczy się najpierw od swoich sąsiadów: porównuje swoje wyniki z ich wynikami i jeśli mają lepsze – naśladuje ich, czyli powielana jest taktyka przynosząca największy sukces[6]. W ten sposób PSO jest symulacją uproszczonego systemu społecznego[7]. W odniesieniu do ludzi, zachowania te są jednak bardziej złożone: poza fizycznym ruchem, ludzie kierują się swoimi poglądami oraz uczuciami w stosunku do innych ludzi.

Z ww. analogii wynikają dwa podstawowe mechanizmy sterujące algorytmami przeszukiwania w PSO:

– eksploracja przestrzeni poszukiwań ukierunkowywana jest na obszar najlepszych znalezionych do tej pory rozwiązań, co skutkuje szybką zbieżnością algorytmu – wadą tego mechanizmu jest to, że zamiast optimum globalnego może zdarzyć się tylko minimum lokalne,

– wykorzystanie informacji o dotychczasowych osiągnięciach w procesie przeszukiwania – tzw. mechanizm jednokierunkowego dzielenia się informacją w PSO: tylko najlepsza lokalna i/lub najlepszy globalny osobnik (tzw. partykl) może przekazać informacje innym osobnikom, a każdy osobnik wykorzystuje oprócz tego swoje własne doświadczenie, pamiętając swoją najlepszą pozycję w przestrzeni potencjalnych rozwiązań.

Zaletami optymalizacji wielocząsteczkowej są:

– niewielka ilość parametrów sterujących procesem optymalizacji,

– wygodna reprezentacja rozwiązań,

– prosta zasada transformacji jednego rozwiązania w inne.

Przy wykorzystaniu PSO musi być zachowana równowaga pomiędzy indywidualnością a zachowaniem grupowym, gdyż:

[6] Można stwierdzić, że podstawą powstania PSO jest założenie, że społeczne dzielenie się informacją pomiędzy osobnikami danej grupy/społeczności stanowi przewagę ewolucyjną.

[7] Fealko D. R. Evaluationg Particle Swarm Intelligence Techniques for solving university examination timetabling problems. Rozprawa doktorska. Nova Southeastern University 2005.

– koncentracja na indywidualności powoduje skupienie na samodzielnym poszukiwaniu rozwiązania, co powoduje „wieczne" poszukiwanie rozwiązania lub zakończenie poszukiwania na pierwszym znalezionym rozwiązaniu ze względu na brak wystarczającej wymiany wiedzy z innymi osobnikami,

– koncentracja na zachowaniu grupowym powoduje skupienie się na czerpaniu korzyści z doświadczeń innych osobników, co z kolei powoduje koncentrację wszystkich cząstek na pierwszym rozwiązaniu spełniającym założone kryteria (czyli np. minimum lokalnym), bez indywidualnych poszukiwań.

Dodatkowo doświadczalnie wiadomo, że częściej mniej liczne sąsiedztwo daje większą efektywność modelu. Sąsiedni nie musi tu oznaczać: znajdujący się w bezpośredniej bliskości, lecz jedynie np. kolejny w rzędzie/kolumnie, a odległości między cząstkami mogą być znaczne.

Algorytmy PSO dobrze rozwiązują szeroki zakres problemów, niezależnie od ilości wymiarów i rozmiaru problemów, a ich rzeczywistą zaletą w porównaniu z innymi algorytmami jest ich prostota i skalowalność. Wybrane zalety PSO obejmują również:

– szybkość rozwiązywania nietypowych problemów,

– zdolność do optymalizacji trudnych problemów matematycznych zarówno w dziedzinie analogowej, jak i cyfrowej.

Systemy wieloagentowe

Jedną z najciekawszych form wykorzystania działania (współdziałania lub rywalizacji) wielu prostych jednostek są systemy wieloagentowe (ang. Multi-Agent Systems – MAS). Podobnie jak w ACO czy PSO wynik ogólny wyłania się ze złożenia działań całej grupy prostych, komunikujących się ze sobą jednostek (agentów) posiadających wbudowane elementarne zasady umożliwiające im realizację lokalnych zachowań będących częścią złożonego zadania (tzw. celu systemu). Z tego punktu widzenia systemy wieloagentowe, składające się z wielu kooperujących ze sobą agentów, stanowią inteligentne oprogramowanie o charakterze rozproszonym.

Definicja agenta napotyka na trudności, gdyż zmienia się zależnie od zadań i zastosowania. W najbardziej ogólnym przypadku agent składa się z dwóch części: informacyjnej (logicznej, programowej) i sprzętowej (fizycznej) reprezentowanej przez robota (maszynę, stację montażową, magazyn itp. w zależności od zastosowania). Niezbędna jest technologia tworzenia oprogramowania, które umożliwia modelowanie oraz implementację indywidualnego i społecznego zachowania w systemach rozproszonych.

System wieloagentowy składa się zazwyczaj z bardziej lub mniej rozbudowanych następujących elementów, takich jak środowisko, obiekty w nim umieszczone i agenci w nim operujący oraz relacje pomiędzy agentami. Stąd system wieloagentowy charakteryzują następujące właściwości:

– składa się z autonomicznych agentów, z których każdy realizuje swoje cele, które mogą lecz nie muszą być wspólne z interesem grupy,

– rodzaj komunikacji określa środowisko,

– podejmowanie decyzji jest rozproszone, tj. każdy agent ma swój poziom autonomii.

Pomiędzy agentami mogą być wymieniane następujące zasadnicze komunikaty: propozycja określonej akcji, akceptacja/odrzucenie akcji, kontrpropozycja na zaproponowaną akcję. Agent, jako forma sztucznej inteligencji, może podjąć próbę komunikacji (np. w wypadku żądania realizacji zadania itp.) lub ją odrzucić (jeśli np. zgodnie z jego logiką i stanem wiedzy kłóciłoby się to z realizacją powierzonego mu zadania). Daje to agentom pewną autonomię w ramach systemu sterującego, co odróżnia je od obiektów w systemach obiektowych[8].

Paradygmaty systemów wieloagentowych są więc następujące:

– reaktywność – postrzeganie zmian zachodzących w otaczającym agenta środowisku i reagowanie na nie w odpowiednim czasie,

– proaktywność – oznaczająca nie tylko reagowanie na zmiany zachodzące w otaczającym środowisku, ale i podejmowanie inicjatywy w celu ich dokonania,

– autonomia agentów – agent może działać samodzielnie bez udziału człowieka oraz innych agentów, a także ma zdolność kontrolowania swoich działań i swojego stanu,

– zdolność do zachowań społecznych – oznaczająca możliwość współdziałania z innymi agentami, w tym także z ludźmi, zdolność do samoorganizacji, łączenia się w grupy itp.,

– racjonalność – agenci działają w taki sposób, by osiągnąć postawione przed nimi cele, stąd tzw. sterowanie przez cele,

– komunikatywność – zdolność do wymiany informacji innymi agentami, z systemem zarządzania, ale również z otoczeniem, m.in. w celu identyfikacji jego i zagrożeń,

– zdolność uczenia się i elastyczność/adaptacja – agenci ciągle poprawiają swoje działanie w czasie,

– mobilność – zdolność do zmiany miejsca w otoczeniu[9].

Zasadnicze zadania wykonywane przez systemy wieloagentowe obejmują: omiatanie otoczenia, przeszukiwanie otoczenia, sterowanie ruchem, ruch w formacji. Mogą je realizować cztery zasadnicze rodzaje agentów:

– agent logiczny – z funkcją decyzyjną implementowaną na podstawie dedukcji,

– agent reaktywny – z funkcją decyzyjną implementowaną w oparciu o analizę stanu otoczenia,

[8] Hakansson A. *Agent and multi agent systems technologies and applications*. Springer Verlag, New York – Heidelberg 2010.

[9] Wooldridge M., Jennings N.R. *Intelligent agents: theory and practice*. The Knowledge Engineering Review, 1995, 10(2): 115-152.

– agent bdi (przekonanie-chęć-zamiar z ang. beliefs-desires-intentions) – z funkcją decyzyjną oparta na danych reprezentowanych jako bdi,

– architektury warstwowe – z funkcją decyzyjną zaszytą w poszczególne warstwy oprogramowania, z których każda odpowiada za inny poziom abstrakcji otoczenia[10].

Podstawowa klasyfikacja technologii wieloagentowych jest następująca:

– wykorzystujące paradygmaty agentowe: Prometheus, Styx, HLIM, Cassiopeia, Tropos, GAIA, MASE, SODA itp.,

– wykorzystujące zasady obiektowe (ang. Object Orientation): MASSIVE, AOMEM, ODAC, AOAD, DESIRE, MASB, AAII itp.,

– oparte na inżynierii wiedzy (ang. Knowledge Engineering – KE): CommonKADS, MASCommonKADS, CoMoMAS itp.,

– oparte na inżynierii wymagań (ang. Requirements Engineering – RE)[11].

System wieloagentowe stanowią więc praktyczną programową realizację rozproszonej sztucznej inteligencji (ang. distributed artificial intelligence – DAI)[12].

Do najważniejszych wojskowych zastosowań systemów wieloagentowych należą:

– wielopoziomowe i adaptacyjne symulacje działań bojowych[13],

– planowanie tras z omijaniem stref zagrożeń,

– realizacja różnorodnych zadań na rzecz utrzymania świadomości sytuacyjnej,

– systemy dowodzenia oraz wsparcia podejmowania decyzji (ang. Interoperable Command & Control based on MultiAgent Systems – IC2MAS),

– wieloagentowe systemy robotów mobilnych.

Wydaje się, że ww. zastosowania będą stanowiły przyszłość tej części techniki wojskowej, która zostanie oparta na środkach autonomicznych (zarówno agentach programowanych, jak i robotach lądowych (w tym poruszających się pod powierzchnią gruntu), pływających i latających. Wpisują się one czytelnie w paradygmat zdolności sieciocentrycznej (ang. Net Enebled Capability) oraz Połączonego Obrazu Operacyjnego (ang. Commn Operational Picture).

[10] Gnatowski M., *Wykorzystanie systemów wieloagentowych we współdziałaniu robotów mobilnych*. Rozprawa doktorska. Instytut Podstawowych Problemów Techniki Polskiej Akademii Nauk, Warszawa 2005.

[11] Alonso F., Frutos S., Martinez L. i wsp., *Towards a natural agent paradigm development methodology*. MATES 2004, LNAI 3187, s. 155–168.

[12] Cetnarowicz K., *Pojęcie M-agenta i koncepcja systemów wieloagentowych*, [w:] Stanek S. (red.) *Rozwój informatycznych systemów wieloagentowych w srodowiskach społeczno-gospodarczych*. Wydawnictwo Placet, Warszawa 2008; Cetnarowicz K., Dreżewski R., Byrski A. i wsp., *Agentowe metody inteligencji obliczeniowej*. [w:] Stanek S. (red.) *Rozwój informatycznych systemów wieloagentowych w środowiskach społeczno-gospodarczych*. Wydawnictwo Placet, Warszawa 2008.

[13] Por. prace B. Kamińskiego z Zakładu Wspomagania i Analizy Decyzji Instytutu Ekonometrii SGH w Warszawie.

Wieloagentowe systemy robotów mobilnych

Przykład efektywnego wykorzystania prezentowanego powyżej zjawiska rozproszenia w zdecentralizowanych systemach wieloagentowych stanowią wieloagentowe systemy robotów mobilnych (ang. multi-agent robots). Odkąd technologicznie dostępne stały się roboty autonomiczne, kolejnym krokiem są próby wykorzystania zespołów takich robotów, współpracujących i komunikujących się ze sobą, aby zrealizować wspólny cel. Jednak w robotyce mobilnej opartej na systemach wieloagentowych, nie ma narzuconego założenia, że jeden robot = jeden agent (tj. robot jako agent upostaciowiony). Ze względu na istnienie co najmniej jednego systemu sterującego operującego w przestrzeni wirtualnej można wyróżnić następujące przypadki relacji robot-agent:

– agent rozszerzony – to agent jednocześnie umiejscowiony w robocie i w systemie sterowania,

– agent umiejscowiony w robocie, z odbiciem w systemie sterowania służącym m.in. do symulacji działania robotów,

– agent zlokalizowany jest w systemie sterowania, a robot to tylko jego narzędzie,

– grupa agentów zlokalizowanych w systemie sterowania, sterujących jednocześnie jednym lub wieloma robotami[14].

Kwestią do rozstrzygnięcia pozostaje jeszcze architektura robota:

– deliberatywna – robot ma wbudowany model otoczenia i dokonuje w nim zmian poprzez kontakt,

– oparta na zachowaniu (behawioralna) – działające bez modelu świata, poznające go w czasie działania i reagujące na jego przejawy,

– hybrydowa, z podziałem zadań na obsługiwane delibaratywnie lub behawioralnie[15].

Przykłady realizacji ww. architektur stanowią: AuRA, CEBOT, ATLANTIS, SSS, TCA, SAPHIRA, ARA, DAMN, 3T, ALLIANCE, BERRA, SWARM-BOTS, YAVUZ, BUSQUETS, VOMAS czy Tripodal Schematic Control Architecture.

Należy zaznaczyć, że agenci nie zawsze będą mieli zgodne cele (np. w przypadku dostępu wielu agentów do tego samego zasobu), stąd nie zawsze da się zastosować strategię opartą np. na poprzednio opisanym ACO zakładającym pełną współpracę wszystkich agentów. Powoduje to konieczność wbudowania pewnych elementów rywalizacji pomiędzy agentami, co może przełożyć się również na przyśpieszenie i zwiększenie efektywności realizacji zadania.

Ogólnie zadania wykonywane przez zespoły robotów można podzielić na dwie klasy:

[14] Gnatowski M., *Wykorzytsanie systemów wieloagentowych we współdziałaniu robotów mobilnych*. Rozprawa doktorska. Instytut Podstawowych Problemów Techniki Polskiej Akademii Nauk, Warszawa 2005.

[15] Tamże.

– zadanie może być wykonane przez pojedynczego robota, ale zespół robotów może wykonać je szybciej lub bardziej efektywnie, m.in. dzięki dekompozycji zadania (np. eksploracja terenu),

– zadanie nie może być wykonane przez pojedynczego robota i tylko zespół składający się z kilku robotów współpracujących ze sobą może wykonać zadanie (np. zadania transportowe).

Zespoły robotów homogenicznych mają możliwość redundancji, tzn. w wypadku awarii jednego z robotów inny robot może go zastąpić i zadanie zostanie wykonane. Z kolei roboty heterogeniczne mają większe spektrum zastosowań, ponieważ pełnią różne funkcje w zespole, niezbędne do realizacji części zadań.

Wieloagentowe systemy robotów mobilnych mogą znaleźć zastosowanie zarówno w przemyśle[16], medycynie (mikroroboty i nanoroboty[17]), jako zaawansowane narzędzia eksploaracyjne i poszukiwawcze, a także na wielu innych polach. Wykorzystanie wieloagentowych systemów robotów mobilnych nie umknęło również inżynierom wojskowym. W epoce sieciocentrycznego pola walki mogą one stanowić znakomite uzupełnienie systemów uzbrojenia, rozpoznania i identyfikacji obiektów czy zagrożeń, wykonując niepostrzeżenie szereg newralgicznych zadań za linią wroga niemal w każdych warunkach pogodowych. Ze względu na swoją liczebność oraz redundancję system homogenicznych wieloagentowych robotów mobilnych (również: latających lub pływających) byłby niezwykle odporny na uszkodzenia: każdy z agentów byłby w stanie zastąpić dowolnego innego w przypadku uszkodzenia. Roboty takie byłyby niezastąpione również w misjach poszukiwawczych i ratunkowych, zarówno w terenie zurbanizowanym, jak i trudno dostępnym czy z innego powodu niedostępnym lub niebezpiecznym do bezpośrednich poszukiwań[18].

Dotychczasowe doświadczenia wskazują, że systemy wieloagentowe robotów mobilnych na potrzeby wojska powinny cechować się:

– elastycznością, w tym możliwością uzupełniania i rozbudowy podczas działania systemu,

[16] Krasiński A., *Wieloagentowy system robotów mobilnych. Opis projektu*. Prace Naukowe Instytutu Cybernetyki Technicznej Politechniki Wrocławskiej, 1998, 98: 241-247; Gnatowski M., Wykorzystanie systemów wieloagentowych we współdziałaniu robotów mobilnych. Rozprawa doktorska. Instytut Podstawowych Problemów Techniki Polskiej Akademii Nauk 2005; Bartyna W., Ambroszkiewicz S. Architektura systemu wielorobotowego, język komunikacji i protokoły. Materiały X Krajowej Konferencja Robotyki, Miechowice 2008; Ambroszkiewicz S., Cetnarowicz K. On situating agents in multi-robot systems. Materiały CS&P'2005 Workshop; Skrzypczyński P. A Team of Mobile Robots and Monitoring Sensors – from Concept to Experiment. Advanced Robotics, 2004, 18(6): 583–610.

[17] Mikołajewska E., Mikołajewski D., *Neurorehabilitacja XXI wieku. Techniki teleinformatyczne*. Impuls, Kraków 2011; Mikołajewska E., Mikołajewski D., *Roboty rehabilitacyjne. Rehabilitacja w Praktyce*, 2010, 4: 49-53.

[18] Looije R., Neerincx M., Kruijff G.-J. M., *Affective collaborative robots for safety & crisis management in the field*. Materiały ISCRAM 2007 – Intelligent Human Computer Systems for Crisis Response and Management 2007.

– zdolnością do realizacji zadania nawet przy bardzo dużych stratach liczebnych lub poważnych uszkodzeniach – dopuszczalne jest wtedy rozwiązanie nie optymalne, lecz pierwsze spełniające minimalne wymagania,

– dostosowaniem do różnych warunków pracy, np. lądowych, w zbiornikach wodnych, w przestrzeni powietrznej czy w próżni,

– możliwość wprowadzenia heterogeniczności (podziału ról),

– możliwością wykonywania zadania przy niepełnych danych, np. w nieznanym terenie lub w warunkach szybko zmieniającego się otoczenia (np. położenia ludzi w otoczeniu),

– możliwością współpracy z pojedynczym żołnierzem lub grupą żołnierzy (ang. collaborative robotics),

– stabilnością,

– dużą efektywnością realizacji zadań.

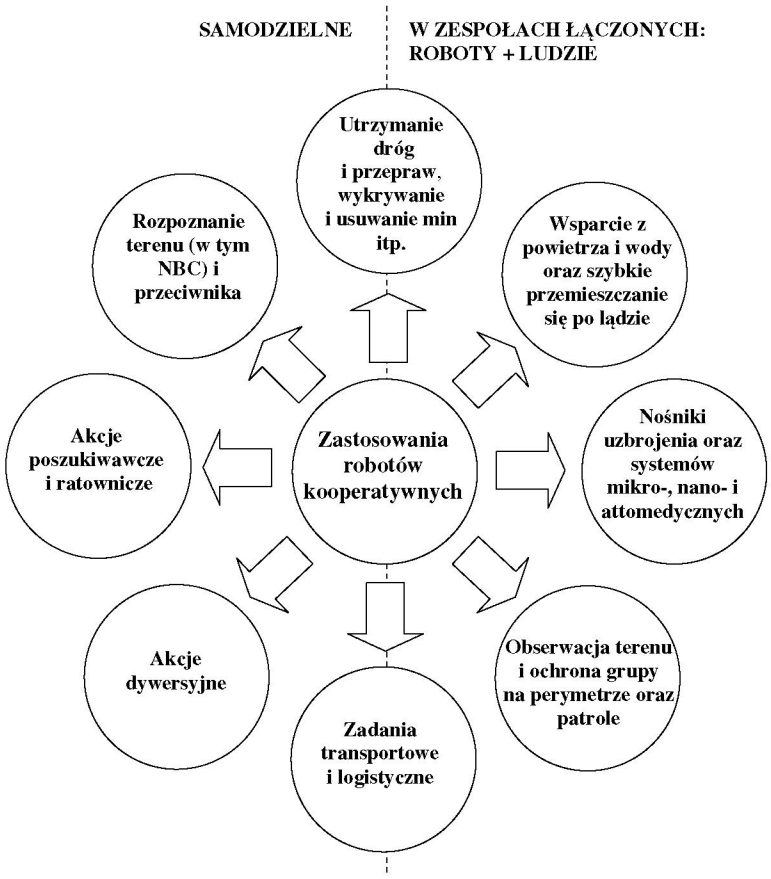
SAMODZIELNE
W ZESPOŁACH ŁĄCZONYCH: ROBOTY + LUDZIE
Utrzymanie dróg i przepraw, wykrywanie i usuwanie min itp.
Rozpoznanie terenu (w tym NBC) i przeciwnika
Wsparcie z powietrza i wody oraz szybkie przemieszczanie się po lądzie
Akcje poszukiwawcze i ratownicze
Zastosowania robotów kooperatywnych
Nośniki uzbrojenia oraz systemów mikro-, nano- i attomedycznych
Akcje dywersyjne
Zadania transportowe i logistyczne
Obserwacja terenu i ochrona grupy na perymetrze oraz patrole

Rys. 1. Wybrane wojskowe zastosowania wieloagentowych systemów robotów mobilnych

Potencjał militarny robotów kooperatywnych został dość wcześnie dostrzeżony[19] – badania nad nimi są prowadzone niemal na całym świecie, również w większości państw NATO. Wiodące ośrodki stanowią:

- DARPA – projekty UltraLog i Cougaar[20],
- NASA Ames Research Center i NASA Glenn Research Center[21],

Początkowo główny wysiłek badań stanowiły rozwiązania przeznaczone do eksploracji przestrzeni kosmicznej, w tym sąsiednich planet. Zastosowania wojskowe tego typu robotów wynikły przede wszystkim z ich umiejętności realizacji zadań w warunkach radzenia sobie z nieprzewidywalnymi zdarzeniami w nieznanym środowisku, nawet przy znacznych stratach własnych. Czyni to z nich niemal idealne rozwiązania do wykorzystania na polu walki.

W Polsce największymi ośrodkami badań nad systemami wieloagentowymi i robotami opartymi na nich są: Instytut Podstaw Informatyki PAN, Akademia Górniczo-Hutnicza w Krakowie oraz Politechnika Poznańska. Wybrane zagadnienia z tej tematyki są badane na większości politechnik i uniwersytetów w naszym kraju, głównie w ramach sztucznej inteligencji i/lub robotyki.

Wnioski

Ze względu na dość wczesny stopień rozwoju prezentowane rozwiązania wymagają jeszcze wielu wysiłków, lat pracy i nakładów finansowych włożonych w badania nad percepcją, nawigacją, planowaniem oraz rozproszonym sterowaniem w wieloagentowych systemach robotów mobilnych. Niemniej jednak, szczególnie w zastosowaniach militarnych, mogą one stanowić istotną alternatywę dla przyszłościowych konwencjonalnych robotów typu humanoidalnego oraz uzupełnienie dla innego dynamicznie rozwijanego przez cywilne i wojskowe ośrodki badawcze typu robota: egzoszkieletu z żywym operatorem[22]. Kluczem do ich szybkiego rozwoju może być interakcja człowiek-maszyna jako umiejętność intuicyjnej współpracy człowieka ze zrobotyzowanym, samodzielnym otoczeniem, zwiększająca jego efektywność na sieciocentrycznym polu walki.

[19] Multi-Robot Systems in Military Domains. RTO TECHNICAL REPORT TR-IST-032/RTG-014.

[20] Por. Integrated Computerized Deployment System (ICODES).

[21] Wong E., Litt J. S. Autonomous multi-agent robotics for inspection and repair of propulsion systems. Materiały AIAA 1st Intelligent Systems Technical Conference 2004.

[22] E. Mikołajewska, D. Mikołajewski, *Egzoszkielet jako szczególna forma robota – zastosowania cywilne i wojskowe*. „Kwartalnik Bellona" 2011, nr 1, s. 160-169; E. Mikołajewska, D. Mikołajewski, *Zastosowania automatyki i robotyki w wózkach dla niepełnosprawnych i egzoszkieletach medycznych*. „Pomiary Automatyka Robotyka", 2011, nr 5, s. 58-64; E. Mikołajewska, D. Mikołajewski, *Exoskeletons in neurological diseases – current and potential future applications*. "Advances in Clinical and Experimental Medicine", 2011, nr 20(2), s. 227–233; E. Mikołajewska, *Neurorehabilitacja. Zaopatrzenie ortopedyczne*. Wydawnictwo Lekarskie PZWL, Warszawa 2009, s. 74–76.